

首都大学東京 平成30年度 特別研究
修士論文

観光地の人気の変化に影響する特徴量の分析

首都大学東京
システムデザイン研究科システムデザイン専攻
情報通信システム学域

学修番号：17890525
氏名：高野 悠作

指導教員：石川 博 教授

平成31年2月22日

論文要旨

近年、スマートフォンやタブレットなどの普及により、Webから容易に有益な情報を得ることが出来るようになってきている。そこで、旅行者が目的地を決定する際の重要な情報源としてTripAdvisorなどの観光情報サイト(観光に関する情報を掲載するウェブサイト)に対する需要が増加している。このような旅行におけるインターネットの重要性の増加と同時に、その利用方法も変化しており、観光情報サイト上のユーザのレビューなどが旅行者の意思決定を左右する重要な情報となっている。これらの観光情報サイトでは、一般的にランキングの形式で観光地を掲載しており、現在までのユーザのレビューにおける評価を基にして観光地のランキングを提案している。したがって、これらの観光情報サイトにおけるランキングは、観光地に対する過去の総合的な評価を基にしたランキングであると考えられる。また、基本的に内部のアルゴリズムに関しては、Google検索などと同様に意図的な操作を避けるために非公開である。

ここで、観光地の人気に関して、観光地にもトレンドが存在する。例えば、イベントや季節などの時間や状況によって観光地の人気は変動する。この時、現在の観光情報サイトにおける観光地のランキングでは、過去に投稿されたユーザのレビューのみを特徴量としてランキングを行うため、新興の観光地や人気の変動が大きい観光地などがランキングの上位に出現しない可能性がある。ユーザが観光スポットを選択するときのニーズとして、来訪時点で最も楽しめる観光地、つまり、季節などのトレンドを考慮した観光地を提案する事は、ユーザへのランキングの提示方法の一つとして考えられる。しかし、一般的にランキングにおいては、ユーザは上位に位置づけられている一部の情報のみを閲覧すると考えられるため、過去に投稿されたレビューのみを特徴量として観光地をランキングすることはユーザのニーズを十分に満たしていない可能性が存在する。例えば、このユーザのニーズに的確な観光地のランキングとしては、新宿御園など桜の名所として有名な観光地などが春の時期には上位に位置している必要がある。そこで本研究では、過去の総合的な評価に加えて、現在時点における人気の変動を考慮した、観光地のランキングを生成することを目的とする。

現在では、Twitterなどのソーシャルメディア上に観光地に対する感想が大量に投稿される。

これらの投稿は観光情報サイトにおけるレビューよりも直近性の高いユーザの感想であり、最近の投稿を観光地のランキングに利用することで、ランキングの改善に寄与すると考えられる。しかし、Twitterは様々な属性を持つユーザが利用をしており、Botによる投稿なども存在する。そのため、投稿における情報の信頼性が低く、Twitterに投稿されたテキストにおける観光地に対する感想や情報のみに基づいて、観光地をランキングすることは非常に困難である。

そこで本研究では、TripAdvisorにおける観光地のランキングに対して、ツイートをを用いてモデル化をする事で観光地のランキングを生成する。TripAdvisorなどの観光情報サイトにおけるレビューでは、各投稿における情報量がTwitterと比較して多く、より詳細な観光地に対する感想が反映されている。また、多くの観光情報サイトが存在する中でもTripAdvisorは最大規模の観光情報サイトであり、そのレビューやコンテンツに対する信頼性と影響が検証されており、多くの旅行者にTripAdvisorが利用されている事が明らかにされている。このTripAdvisorにおける観光地のランキングから生成したモデルに対して、最近の観光地におけるツイートを適用することにより、人気の時間変化の考慮した観光地のランキングを生成する。これにより、ユーザが実際に目にする機会が多いランキングの上位に対して、イベントや季節などのトレンドを考慮した観光地が位置することになり、ユーザのニーズの一つである来訪時点で最も楽しめる観光地を満たすようなランキングの提案が可能になる。

これらの観光地のランキングに対して影響する特徴量は非常に複雑であると考えられる。そこでまず、観光地のランキングにおいて人気に影響する特徴量の分析を言語的特徴量と統計的特徴量の2つの観点から行う。観光地におけるツイートに対して、回帰分析を用いて各特徴量の寄与率や順位相関を算出した上で有効な特徴量の分析を行う。それらの分析結果を踏まえて、各特徴量に対してランキング学習を用いて観光地のランキングのモデル化を行う。このモデルに対して、最近のツイートを適用する事でトレンドを考慮した観光地のランキングを生成した上で、その結果における有用性に対して考察と検証をした。

本稿の構成は以下の通りである。第2章では、インターネット上の投稿における特徴量分析と観光地推薦における関連研究について述べる。第3章では、ツイートにおける言語的特徴量と統計的特徴量に関する分析の結果と考察について述べる。第4章では、回帰分析を用いて特徴量について評価した上で、ランキング学習を適用した結果について述べる。第5章では、得られた結果に対する考察を述べる。第6章では、まとめと今後の展望について述べる。

目次

論文要旨	i
第1章 はじめに	1
第2章 関連研究	3
2.1 Webにおけるユーザレビューの分析	3
2.2 観光地の推薦	3
第3章 観光地における特徴量の分析	5
3.1 データセット	5
3.2 観光地における言語的特徴量の考察	6
3.3 観光地における統計的特徴量の考察	8
3.4 観光地における統計的特徴量の変化に対する考察	11
第4章 実験	15
4.1 特徴量における回帰分析	15
4.2 ランキング学習	18
第5章 考察	22
第6章 まとめと今後の課題	25
謝辞	26
参考文献	27
発表論文	30

第1章

はじめに

近年、スマートフォンやタブレットなどの普及により、Webから容易に有益な情報を得ることが出来るようになってきている。そこで、旅行者が目的地を決定する際の重要な情報源としてTripAdvisor^{*1}などの観光情報サイト(観光に関する情報を掲載するウェブサイト)に対する需要が増加している。このような旅行におけるインターネットの重要性の増加と同時に、その利用方法も変化しており、観光情報サイト上のユーザのレビューなどが旅行者の意思決定を左右する重要な情報となっている [1] [2]。これらの観光情報サイトでは、一般的にランキングの形式で観光地を掲載しており、現在までのユーザのレビューにおける評価を基にして観光地のランキングを提案している。したがって、これらの観光情報サイトにおけるランキングは、観光地に対する過去の総合的な評価を基にしたランキングであると考えられる。また、基本的に内部のアルゴリズムに関しては、Google検索などと同様に意図的な操作を避けるために非公開である。

ここで、観光地の人気に関して、観光地にもトレンドが存在する。例えば、イベントや季節などの時間や状況によって観光地の人気は変動する。この時、現在の観光情報サイトにおける観光地のランキングでは、過去に投稿されたユーザのレビューのみを特徴量としてランキングを行うため、新興の観光地や人気の変動が大きい観光地などがランキングの上位に出現しない可能性がある。ユーザが観光スポットを選択するときのニーズとして、来訪時点で最も楽しめる観光地、つまり、季節などのトレンドを考慮した観光地を提案する事は、ユーザへのランキングの提示方法の一つとして考えられる。しかし、一般的にランキングにおいては、ユーザは上位に位置づけられている一部の情報のみを閲覧すると考えられるため、過去に投稿されたレビューのみを特徴量として観光地をランキングすることはユーザのニーズを十分に満たしていない可能性が存在する。例えば、このユーザのニーズに的確な観光地のランキングとしては、新宿御園など桜の名所として有名な観光地などが春の時期には上位に位置している必要があ

^{*1} <https://www.tripadvisor.com/>

る。そこで本研究では、過去の総合的な評価に加えて、現在時点における人気の変動を考慮した、観光地のランキングを生成することを目的とする。

現在では、Twitter^{*2}などのソーシャルメディア上に観光地に対する感想が大量に投稿される。これらの投稿は観光情報サイトにおけるレビューよりも直近性の高いユーザの感想であり、最近の投稿を観光地のランキングに利用することで、ランキングの改善に寄与すると考えられる。しかし、Twitterは様々な属性を持つユーザが利用をしており、Botによる投稿なども存在する。そのため、投稿における情報の信頼性が低く、利用する情報の選定が非常に重要である [3]。また加えて、Twitterの投稿には文字制限があるため、情報量が少なく、投稿されたテキストにおける観光地に対する感想や情報のみに基づいて、観光地をランキングすることは非常に困難である。

そこで本研究では、TripAdvisorにおける観光地のランキングに対して、ツイートを用いてモデル化をする事で観光地のランキングを生成する。TripAdvisorなどの観光情報サイトにおけるレビューでは、各投稿における情報量がTwitterと比較して多く、より詳細な観光地に対する感想が反映されている。また、多くの観光情報サイトが存在する中でもTripAdvisorは最大規模の観光情報サイトであり、そのレビューやコンテンツに対する信頼性と影響が検証されており、多くの旅行者にTripAdvisorが利用されている事が明らかにされている [4]。このTripAdvisorにおける観光地のランキングから生成したモデルに対して、最近の観光地におけるツイートを適用することにより、人気の時間変化の考慮した観光地のランキングを生成する。これにより、ユーザが実際に目にする機会が多いランキングの上位に対して、イベントや季節などのトレンドを考慮した観光地が位置することになり、ユーザのニーズの一つである来訪時点で最も楽しめる観光地を満たすようなランキングの提案が可能になる。

本稿の構成は以下の通りである。第2章では、インターネット上の投稿における特徴量分析と観光地推薦における関連研究について述べる。第3章では、ツイートにおける言語的特徴量と統計的特徴量に関する分析の結果と考察について述べる。第4章では、回帰分析を用いて特徴量について評価した上で、ランキング学習を適用した結果について述べる。第5章では、得られた結果に対する考察を述べる。第6章では、まとめと今後の展望について述べる。

^{*2} <https://twitter.com/>

第2章

関連研究

本章では、まず、インターネット上のユーザレビューにおける特徴量に対する分析の関連研究について述べる。次に、様々な手法を用いたユーザへの観光地推薦の関連研究について述べる。

2.1 Webにおけるユーザレビューの分析

現在では、インターネット上におけるユーザのレビューが増加しており、これらのレビューを基にした研究が活発に行われている。Mukherjeeら [5]はAmazon Mechanical Turkにおけるスパムフィルタのシステムから、Yelp^{*1}におけるスパムフィルタを再現を目的として、言語的特徴量とユーザ行動に関する特徴量の2つの観点から考察している。また、Guyら [6]はTripAdvisorにおける言語的特徴量の観点から考察した上で、ユーザのレビューから観光に役立つ情報を自動的に収集する手法を提案している。そこで本稿では、TripAdvisorにおける観光地のランキングに対して言語的特徴量と統計的特徴量の2つの観点に分けることで、有効な特徴量を考察した上でモデル化を行う。

2.2 観光地の推薦

Twitterなどのソーシャルメディアへの観光地に関する投稿も増加している。これらのソーシャルメディア上の投稿は観光情報サイトにおけるレビューよりも直近性の高いユーザの感想であり、これらを観光地の推薦システム等に応用する研究も盛んに行われている。Borrasら [7]はこれらの推薦システムを技術的に分類した上でこれらの旅行におけるその重要性に対して考察している。Lohら [8]はWeb上におけるユーザ投稿を基にした言語的特徴量からユーザ

^{*1} <https://www.yelp.com/>

に的確な観光地を推薦するシステムの提案をしている。Yeら [9, 10]はFoursquare^{*2}におけるチェックイン情報とユーザ属性からPoint Of Interests (POIs)などの地理的情報を推薦する手法を提案している。Deら [11]や、Limら [12]はFlickr^{*3}におけるユーザの行動情報からPOIsを推薦する手法を提案している。Ishiharaら [13]はTwitterにおける投稿を感性工学の観点から考察し、観光地を推薦するシステムを提案している。Mizutaniら [14]はTwitter等のソーシャルメディア上の投稿を利用することで、よりユーザ個人に適合した観光スポットを推薦するシステムの提案を行なっている。

これらの研究では、一般的に推薦システムに対して外的要因などに基づく変化が与える影響について考慮していない。しかし、Missaouiら [15]は観光におけるユーザ嗜好の変化を推定する手法を提案しており、ユーザに対する情報の推薦において、嗜好や環境の変化を考慮する重要性を指摘している。また加えて、既存の研究では観光地の推薦システムに対して、ソーシャルメディア上における投稿やメタデータのみから分析を行っている。しかし、第1章で述べたように、ソーシャルメディア上にはノイズとされるデータが多く情報の信頼性にも問題がある。そこで本研究では、ツイートにおける特徴量に対してロジスティック回帰における寄与率から考察を行った上で特徴選択を行う。そして、TripAdvisorを基にモデル化をすることで人気の変化を考慮した観光地のランキングを生成する。

Twitterデータを利用したランキングでは様々な手法が提案されており、Duanら [16]はTwitter上の投稿に対する検索において、ランキング学習を利用したランキング推薦の提案を行なっている。Quptaら [17]はTwitterにおける様々な言語的特徴量から重要なイベントをランキング形式で推薦する手法を提案している。Changら [18]はTwitterにおける投稿から、検索におけるランキングに対して直近性の不足を改善する手法を提案している。本研究では、ランキング手法の一つであるランキング学習をツイートに対して適用する事により、ランキングのモデル化を行う。

^{*2} <https://foursquare.com/>

^{*3} <https://www.flickr.com/>

第3章

観光地における特徴量の分析

本章では、観光地でのツイートにおける特徴量を言語的特徴量と統計的特徴量の2つの観点から考察する。TripAdvisorにおける観光地のランキングを正確にモデル化するため、各観光地の特徴量を分析した上で分類における有用性に対して考察する。

3.1 データセット

本研究では、2017年の1月1日から2017年の12月31日までの1年間において、東京で投稿された位置情報付きのツイートを利用した。その結果として、東京都内における全日本語のツイートで6,249,522件であった。ここで、観光地の分析において投稿者の感想や意見を含まないリツイートやFoursquareにおけるチェックインなどのツイートは前処理として除いている。これらのツイートにおいて分析の対象となる観光地の敷地内で投稿されたツイートのみを利用する。

この分析の対象とする観光地としては、2017年に取得したTripAdvisorにおける東京の観光地のランキング上位100件を用いる。ただし、これらの観光地において、各月別での季節などの変化に対しても分析を行うため、毎月100件以上のツイートが確認できる観光地のみを分析対象とした。各観光地で投稿されたツイートの抽出にはGooglePlaceAPI^{*1}とNominatimAPI^{*2}を利用している。各観光地におけるツイートを正確に抽出するため、それぞれのAPIを利用して観光地の範囲を取得した。この時、各APIにおいて対応していない観光地が存在するためGooglePlaceAPIとNominatimAPIの両方を用いて収集を行っている。ツイートに付与されている緯度経度が取得した観光地の範囲の中に位置している場合には、その観光地で投稿されたツイートとして本実験に利用した。結果として、観光地のランキング上位100件において、毎月100件以上のツイートが確認できる観光地は50箇所存在しており、これらの観光地における2017年内の日本語のツイートは総計で1,691,521件であった。

^{*1} <https://cloud.google.com/maps-platform/places/>

^{*2} <https://nominatim.openstreetmap.org/>

3.2 観光地における言語的特徴量の考察




図3.1 各観光地のUnigramにおけるKL-Divergence

表3.1 各観光地のUnigramにおける偏向性の高い単語上位5件

順位	Class1	Class2	Class3	Class4	Class5
1	台東区	大田区	渋谷区	大田区	大田区
2	原宿駅	東京国際空港	渋谷駅	台東区	東京国際空港
3	東京国際空港	羽田空港旅客ターミナル	世田谷区	東京国際空港	羽田空港旅客ターミナル
4	渋谷区	中央区	東京国際空港	羽田空港旅客ターミナル	台東区
5	東京テレポート駅	羽田空港	東京テレポート駅	東京テレポート駅	羽田空港
順位	Class6	Class7	Class8	Class9	Class10
1	原宿駅	大田区	東京テレポート駅	大田区	豊島区
2	渋谷区	台東区	台東区	日本武道館	渋谷区
3	神保町駅	港区	日本武道館	港区	サンシャインシティ
4	台東区	新宿区	渋谷区	墨田区	日暮里駅
5	東京国際空港	日本武道館	東京国際空港	東京テレポート駅	荒川区

初めに、各観光地における言語的特徴量の分布に対して考察をする。言語的特徴量の分布においては、各観光地におけるツイートの投稿文書内の単語確率分布であるUnigramを比較する。ただし、各観光地におけるランキング上の順位を基にして、階級幅を10として

{Class1, Class2, ..., Class10}の階級数10に分割した上で比較を行った。各ツイートにおける投稿に対しては形態素解析による前処理を行っており、これにはMecab^{*3}を利用した。このとき、形態素解析に用いる辞書としては、IPA辞書を新語や固有表現に対して拡張したmecab-ipadic-NEologd^{*4}を用いた。また、Unigramの抽出には、The Kyoto Language Modeling Toolkit^{*5}におけるGood-Turing smoothed unigram language modelを利用した。

図 3.1は、言語的特徴量による分類の有用性を検証するため、対象の観光地において2017年内に投稿されたツイートにおけるUnigram間の距離をKullback-Leibler Divergence (KL-Div)を用いて比較した結果である。ただし、KL-Divは距離の公理である対称性を持たないため、正確に距離として定義することはできない。この対称性の問題を改善したJensen-Shannon Divergence (JS-Div)も広く利用されているが、非対称性に基づく計算順序の入れ替えによる変化に対しても着目するためKL-Divを用いた。結果として、各階級ごとにKL-Divに一定以上の差異があることが確認できる。また、ランキングにおける順位が低い観光地の属する階級では、他の階級に対するKL-Divの差異が大きく特殊な単語分布を持っていると考えられる。加えて、各月別での対象観光地におけるUnigramにおいても同様の分析を行なったが、類似した傾向が見て取れた。以上より、言語的特徴量は単語確率分布では各観光地において差異があり、分類においては寄与する特徴量であると考えられる。

表 3.1では、各階級間におけるKL-Divに対して各単語がもつ寄与率を比較した上で、偏向性が高い単語を検出している。その結果、全体を通して、地名、駅名、施設名などの地理的な名詞が上位を全て占有していることが確認できる。また、各月別でのUnigramにおける偏向性の高い単語を検証した場合にも、同様の結果が確認できた。これは特定の階級に一部の地域や施設に位置する観光地が多く所属しているため、その地域名などを含むツイートが多く投稿された為だと考えられる。しかし、特定の地域への所属という観光地の地理的な要因とランキングにおける順位との間に関係性があるかは検証の必要がある。例えば、浅草寺などは台東区に位置しているから人気があり、ランキングにおいても上位に位置しているとは考えにくい。したがって、各観光地のツイートに対する前処理の段階でこれらの地理的な名詞を除くことも考慮する必要がある。以上の結果より、言語的特徴量では単語分布間で一定の差異が存在しており、分類に対して一定の寄与をすると考えられる。ただし、地理的な単語などノイズとなる特徴量も多く存在するため前処理と特徴量選定が非常に重要であると考えられる。

^{*3} <http://taku910.github.io/mecab/>

^{*4} <https://github.com/neologd/mecab-ipadic-neologd>

^{*5} <http://www.phontron.com/kylm/>

3.3 観光地における統計的特徴量の考察

表3.2 観光地の各統計量における次元間の正負の平均相関係数

投稿曜日	投稿時間	投稿文字数	投稿絵文字数	投稿顔文字数	投稿数	連続投稿数	再来訪数
0.52	0.40	0.22	0.29	0.51	0.20	0.22	0.44




図3.2 ツイートの投稿曜日における累積確率分布

次に、各観光地における統計的特徴量の分布に対して考察をする。統計的特徴量の分布においては、各観光地におけるツイート別の統計量である投稿曜日、投稿時間、投稿文字数、投稿絵文字数、投稿顔文字数における累積確率分布と、各観光地におけるユーザ別の統計量である投稿数、連続投稿数、再来訪数における累積確率分布を比較する。ただし、各観光地におけるランキング上の順位を基にして、階級幅を10として $\{Class1, Class2, \dots, Class10\}$ の階級数10に分割した上で比較を行った。

まず初めに、各観光地においてツイート別で集計した統計的特徴量の累積確率分布に対して考察する。図 3.2は各階級におけるツイートの投稿曜日の累積確率分布である。横軸は0を月曜日として6を日曜日とした1週間における各曜日を示している。結果として、全階級において累積確率分布に一定の差異が存在することが確認できる。また、全体を通して、平日(0-4)と比較




図3.3 ツイートの投稿時間における累積確率分布

して休日(5-6)における傾きが大きくなっており、投稿数が増加していることが分かる。次に、図 3.3は各階級におけるツイートの投稿時間の累積確率分布であり、横軸は1日における各時刻を表している。投稿時間でも図 3.2と同様に階級ごとに一定の差異が存在することが確認できる。特に、日中(6-18)と夜間(0-5, 18-23)における差異が大きく、各観光地によって来訪者数が増加する時間帯が異なるため、ツイートの投稿数においても差異が生じていると考えられる。したがって、時間における投稿数の変化という観点では、ランキング上の各観光地で分布に差異が存在しており、分類において一定の寄与をする特徴量であると考えられる。

図 3.4は各階級におけるツイートの投稿文字数の累積確率分布であり、横軸は各ツイートにおける文字数を示している。各観光地において、投稿文字数は大部分のツイートが5文字から15文字で投稿されることが分かる。しかし、各観光地において文字数に一定の差異があり、短文のツイートが多い観光と比較的長文のツイートが多い観光地があることが見て取れる。図 3.5は各階級におけるツイートの投稿絵文字数の累積確率分布であり、横軸は各ツイートに含まれる絵文字数を表している。結果として、全階級において累積確率分布に大きな偏りが存在することが確認できる。多くの観光地において、絵文字が含まれない投稿が大部分を占めていることが分かる。したがって、特徴量において各次元間の差異が小さいため分類に寄与しない特徴量であると考えられる。また加えて、図 3.6は各階級におけるツイートの投稿顔文字数




図3.4 ツイートの投稿文字数における累積確率分布

の累積確率分布であるが、図 3.5と同様に累積確率分布が大きな偏りがあり、大部分の投稿において顔文字が含まれていないことが見て取れる。つまり、各階級間における特徴量の差異が小さく、分類には寄与しないと考えられる。したがって、投稿における内容の変化という観点では、投稿文字数においてのみ一定の差異が存在しており分類に寄与をすると考えられる。

次に、各観光地においてユーザ別で集計した統計的特徴量の累積確率分布に対して考察する。図 3.7は各階級におけるユーザ別の投稿数の累積確率分布である。横軸は各ユーザにおける観光地での投稿数を示している。結果として、全階級を通して投稿数1回と2回に対して分布が偏っていることが分かる。しかし、各観光地におけるユーザの投稿数には差異があり、分類に対して一定の寄与をする特徴量であると考えられる。図 3.8は各階級におけるユーザ別の連続投稿数の累積確率分布であり、横軸は各ユーザにおける30分以内での連続の投稿数を表している。全階級を通して、多くのユーザが連続での投稿をしていないため、累積確率分布にも大きな偏りがある。したがって、特徴量において各次元間の差異が小さく、分類に寄与しない特徴量であると考えられる。図 3.9は各階級におけるユーザ別の再来訪数の累積確率分布であり、横軸は各ユーザにおける1日以上の間隔を開けた上での観光地への再来訪数を示している。図 3.8と同様に累積確率分布が大きな偏りがあり、多くのユーザが観光地に再来訪をしていないことが分かる。つまり、各階級間における特徴量の差異が小さく、分類には寄与しないと考




図3.5 ツイートの投稿絵文字数における累積確率分布

えられる。したがって、各観光地におけるユーザ行動の変化という観点では、投稿数においてのみ差異が存在しており、分類において一定の寄与をする特徴量であると考えられる。

また加えて、表 3.2は観光地の各統計量における次元間の平均相関係数である。投稿曜日と投稿顔文字数における次元間の平均相関係数が高く、回帰分析において結果に悪影響を及ぼす可能性があると考えられる。以上の結果より、統計的特徴量では分布間で一定の差異が存在しており、投稿曜日や投稿時間、投稿数などの一部の統計量においては分類に対して一定の寄与をすると考えられる。ただし、投稿曜日においては、回帰分析における多重共線性に注意が必要である。

3.4 観光地における統計的特徴量の変化に対する考察

次に、各観光地における統計的特徴量の分布の変化に対して考察をする。統計的特徴量としては、第 3.3章におけるツイート別とユーザ別の統計量の変化に加えて、各観光地における月別の総投稿数の変化を用いる。一般的に、統計的特徴量は言語的特徴量と比較して、各観光地における変化の影響を受けやすい特徴量であると考えられる。例えば、特定の観光地における来訪者数が増加した場合には、観光地内でのツイートの投稿数が増加すると推測される。これは、観光地のランキングにおいて人気の変化を考慮する上で非常に重要な特徴量であり、一時




図3.6 ツイートの投稿顔文字数における累積確率分布

的にトレンドとなる観光地ではツイートのバーストなどが検知できると考えられる。

図 3.10は東京都の北の丸公園における月別の総投稿数の変化を示している。各月における公園内での総投稿数に大きな変化があることが見て取れる。また、北の丸公園は桜と紅葉の名所として有名な観光地であり、桜の季節である3月と紅葉の季節である10月に総投稿数がバーストしていることが確認できる。このことから、観光地における総投稿数の変化は観光地におけるトレンドを顕著に表す特徴量であると考えられる。お台場などにおいても同様の傾向が確認されており、花火大会など多くのイベントが開催される8月に観光地内での総投稿数のバーストが検出されている。




図3.7 ユーザの投稿数における累積確率分布




図3.8 ユーザの連続投稿数における累積確率分布




図3.9 ユーザの再来訪数における累積確率分布




図3.10 北の丸公園における総投稿数の変化

第4章

実験

本章では、TripAdvisorの東京都の観光地のランキングにおける上位100件の観光地を正解データとしてランキング学習を行いモデルを生成する。はじめに、ロジスティック回帰を用いた上で各特徴量の有用性を分析し、その結果に基づきランキング学習を適用した上で考察する。また、ランキング学習においては、Joachimsら [19]の提案するSupport Vector Machine (SVM)を基にしてケンドールの順位相関係数の最適化を行うことで、ランキングをモデル化するRanking SVM (RankSVM)を用いる。このとき、TripAdvisorにおける観光地のランキングを正確にモデル化するため、観光地における各特徴量の分類での有用性に加えて、順位相関の存在にも着目して分析する。

4.1 特徴量における回帰分析

表4.1 言語特徴量における学習モデルの平均サブセット精度

特徴量	分類精度 (+/- 誤差)
Unigram	0.90 (+/- 0.02)
Unigram + IG	0.71 (+/- 0.02)
Unigram + TFIDF	0.92 (+/- 0.01)
Bigram	0.94 (+/- 0.01)
POS Unigram	0.26 (+/- 0.03)
Word2Vec	0.38 (+/- 0.03)

ここでは、ロジスティック回帰によってTripAdvisorにおける観光地のランキングを学習した上で、その寄与率からランキング学習に有効な特徴量を分析する。機械学習を用いた分類において、各次元の寄与率を検証する手法はランダムフォレストやSVMなど様々なアルゴリズムを用いた手法が存在する。しかし、ロジスティック回帰を用いることで、分類における

表4.2 ロジスティック回帰における分類寄与率に対するスパイアマン順位相関係数0.4以上の
単語上位20件

単語	順位相関係数
コレクション	0.6261
キレイ	0.6071
歩く	0.5860
てる	0.5784
到る	0.5599
ビビる	0.5342
食事	0.5227
かう	0.4644
昨夜	0.4512
あう	0.4497
お客様	0.4369
良さ	0.3802
いっぱい	0.3717
流れる	0.3438
組み合わせ	0.3294
バレエ	0.3273
おっさん	0.3082
職場	0.2948
付近	0.2648
座る	0.2357

各次元の寄与率を正負の両方向に対して検証すること可能である。ロジスティック回帰の実装は、scikit-learn^{*1}のアルゴリズムを利用しており、最適化のために5交差検定でのグリッドサーチを行った。本実験では、学習する特徴量としては、第3章で分析をした言語的特徴量と統計的特徴量を用いる。言語的特徴量としては、Unigram, Bigram, Part-Of-Speech (POS) Unigram, Word2Vecを用いた。ただし、Unigramに対してはInformation Gain (IG), Term Frequency-Inverse Document Frequency (TFIDF)における次元削減を特徴量に適用した。この次元削減においては、IGとTFIDFのそれぞれにおいて平均値を下回る次元を削減した。統計的特徴量としては、第3.1節におけるツイート別の統計量、ユーザ別の統計量とそれらを組み合わせた全統計量を用いる。また、言語的特徴量と統計的特徴量の両特徴量に対して、正解データを各観光地におけるランキング上の順位を基にし、階級幅を10として{*Class1*, *Class2*,

^{*1} <http://scikit-learn.org/stable/>

表4.3 統計的特徴量における学習モデルの平均サブセット精度

特徴量	サブセット精度 (+/- 誤差)
全統計量	0.39 (+/- 0.03)
全統計量 - 投稿絵文字数 - 投稿顔文字数	0.40 (+/- 0.03)
ツイートに関する統計量	0.58 (+/- 0.02)
ユーザに関する統計量	0.25 (+/- 0.04)
投稿曜日 + 投稿時間 + 投稿文字数	0.64 (+/- 0.05)

表4.4 各統計量における変化を加えた特徴量における学習モデルの平均サブセット精度

特徴量	サブセット精度 (+/- 誤差)
全統計量 + 各統計量の変化	0.35 (+/- 0.03)
ツイートに関する統計量 + 各統計量の変化	0.54 (+/- 0.04)
ユーザに関する統計量 + 各統計量の変化	0.21 (+/- 0.03)
投稿曜日 + 投稿時間 + 投稿文字数 + 各統計量の変化	0.62 (+/- 0.03)

..., *Class10*}の階級数10に分割した上で学習を行った。

表 4.1は、言語的特徴量に対してのロジスティック回帰における平均サブセット精度である。サブセット精度では、各データを個別に比較した上で精度を検証するのではなく、各データにおける集合を比較する。このとき、テストデータに対して予測されるラベルの集合が正解データのラベルの対応する集合と正確に一致する場合に1をとり、それ以外の場合には0をとる。結果として、言語的特徴量においてはUnigram + TFIDFにおける学習モデルとBigramにおける学習モデルが高い性能を記録した。しかし、Unigram + TFIDFにおける次元数3521がBigramにおける次元数1203938と比較して非常に低次元であるため、有用な特徴量選択がされていると考えられる。そこで本実験では、言語的特徴量としてはUnigram + TFIDFをランキング学習に適用した上で分析と検証を行う。表 4.2は、このUnigram + TFIDFにおける学習モデルに対して、分類における各次元の寄与率からスパイマンの順位相関係数が0.4以上となる単語の分類寄与率の上位20件である。ランキング上位には季節的なイベントを指していると考えられる“コレクション”や、観光地に対する好意的な印象となる単語である“キレイ”等が上位に位置している事が確認できる。したがって、分類において一定の順位相関のある特徴量を選択することで、ランキングの学習において有用な特徴量が選択される可能性があると考えられる。そこで、通常の特徴量に加えて、回帰分析において寄与率の順位相関が高い特徴量を選定した上での、観光地のランキングにおけるランキング学習の結果に対しても比較と考察をする。

表 4.3は、統計的特徴量に対してのロジスティック回帰における平均サブセット精度である。結果として、第 3.2章において一定の差異が確認できなかった投稿絵文字数や投稿顔文字数が分類に対して寄与しないことがわかる。また、ツイート別の統計量とユーザ別の統計量における特徴量では、ツイート別の統計量を利用した時の平均サブセット精度が高く、これに対して投稿絵文字数と投稿顔文字数を除く事でより高い分類精度を記録した。そこで本実験では、統計的特徴量として、投稿曜日 + 投稿時間 + 投稿文字数をランキング学習を用いた上で検証をする。表 4.4は、各統計量における変化を特徴量としたロジスティック回帰における平均サブセット精度である。このとき、全ての統計量において変化を考慮することによって分類の性能が低下しており、各観光地を分類する上では統計量の変化による有用性が確認できない。しかし、第 3.3章において述べたように、一般的に、観光地内のツイートの投稿数の変化などは観光地における人気の変化を顕著に反映していると推測される。したがって、これは正解データとなるTripAdvisorにおける観光地のランキングに、各観光地における短期的な人気の変化が考慮されていないため、統計量の変化が寄与しなかったと考えられる。そこで、各特徴量において観光地のランキングを正確にモデル化した上で、直近のツイートを用いてスコアを算出する過程において、各観光地における統計量の変化を追加で反映する必要があると考えられる。以上の結果を基にして、分類において有用性が高い特徴量を用いて観光地のランキングを学習する。また同時に、各次元における分類への寄与率から順位相関が高い次元を選定した特徴量におけるランキング学習の結果との比較を行う。

4.2 ランキング学習

表4.5 ランキング学習モデルの特徴量別精度比較。 言語的特徴量: Unigram + TFIDF, 統計的特徴量: 投稿曜日 + 投稿時間 + 投稿文字数

特徴量	ペアワイズ精度	平均NDCG
言語的特徴量	0.8864	0.8918
統計的特徴量	0.6666	0.1741
言語的特徴量 + 統計的特徴量	0.8329	0.7692
言語的特徴量 (順位相関係数 > 0.4)	0.7915	0.8998
統計的特徴量 (順位相関係数 > 0.4)	0.6440	0.2038
言語的特徴量 + 統計的特徴量 (順位相関係数 > 0.4)	0.8528	0.8075

ここでは、RankSVMを用いてTripAdvisorにおける観光地のランキングをモデル化する。ただし、RankSVMでは学習の収束までに非常に多くの計算量が必要であるという問題点が存在する。そこで本実験では、Leeら [20]の提案するRankSVMにおいて変数削減や計算の効率

表4.6 TripAdvisorにおける観光地のランキングとTwitterにおける観光地のランキングの上位15件

順位	TripAdvisor	Twitter	Twitter (順位相関係数 > 0.4)
1	両国国技館	国立新美術館	サンシャインシティ
2	浅草	サンシャインシティ	サンシャイン水族館
3	六本木ヒルズ	サンシャイン水族館	国立新美術館
4	千鳥ヶ淵	東京国際フォーラム	東京国際フォーラム
5	八芳園	Bunkamura	Bunkamura
6	明治神宮	六本木	アメヤ横丁
7	東京ジャーミイ・トルコ文化センター	谷中霊園	スバラクア
8	浅草寺	お台場パレットタウン	思い出横丁
9	東京都庁	銀座並木通り	六本木
10	東京国立博物館	アメヤ横丁	東京キャラクターストリート
11	キッザニア東京	両国	北の丸公園
12	迎賓館赤坂離宮	思い出横丁	千鳥ヶ淵
13	羽田空港	北の丸公園	銀座並木通り
14	シーサイドトップ展望台	東京ドーム	両国
15	築地市場	皇居外苑	葛西臨海公園

化を行い高速化されたアルゴリズムを用いる。ランキング学習においては様々なアルゴリズムが存在するが、RankSVMはペアワイズにおけるランキング学習のアルゴリズムの1つである。ペアワイズにおけるランキング学習では、学習過程においてデータ全体における集合から2個のデータを順番に選択した上で比較を行いランキングを学習する。RankSVMの実装には、Changら [21]によるLIBSVMを利用し、最適化のために5交差検定でのグリッドサーチを行った。RankSVMでの学習における特徴量としては、第4.1章において分類に有用と考察される言語的特徴量としてはUnigram + TFIDF、統計的特徴量としては投稿曜日 + 投稿時間 + 投稿文字数を用いた。また、それぞれの特徴量において第4.1章における分類寄与率に対してスピアマンの順位相関係数により特徴量選択を行なった場合との比較を行う。

表4.5は各特徴量に対してRankSVMを適用した学習モデルにおけるペアワイズでの分類精度とNormalized Discounted Cumulative Gain (NDCG)の平均値である。ここで、NDCGとは広く使われているランキング学習における予測結果指標であり、Discounted Cumulative Gain (DCG)を正規化した値である。DCGはJärvelin [22]らの提案する以下の計算式を用いて算出した。

$$DCG = \sum_{i=1}^k \frac{rel_i}{\log_2(i+1)} \quad (4.1)$$

このとき、 rel_i はランキングにおける*i*番目の要素の適合度、 k は評価に用いる要素数を表す。NDCGは0から1の値を取り、1に近いほど正解データに適合するランキング結果であることを示す。結果として、言語的特徴量と統計的特徴量のそれぞれにおいてスピアマンの順位相関係

表4.7 Twitterにおけるツイートの総投稿数の変化を考慮した観光地のランキングの上位15件

順位	Twitter	Twitter (順位相関係数 > 0.4)
1	東京国際フォーラム	東京国際フォーラム
2	国立新美術館	サンシャイン水族館
3	サンシャイン水族館	サンシャインシティ
4	お台場パレットタウン	国立新美術館
5	東京ドーム	日本武道館
6	サンシャインシティ	Bunkamura
7	日本武道館	東京ドーム
8	神田明神	思い出横丁
9	Bunkamura	六本木
10	六本木	東京キャラクターストリート
11	アメヤ横丁	アメヤ横丁
12	両国	皇居外苑
13	銀座並木通り	北の丸公園
14	思い出横丁	千鳥ヶ淵
14	北の丸公園	お台場パレットタウン

数における特徴量選択を行うことでNDCGの値が改善しており、両特徴量を組み合わせた上での学習においても高い性能を記録した。ただし、言語的特徴量と統計的特徴量を順位相関に基づいて特徴量選択をした場合には、NDCGは改善するがペアワイズにおける分類性能が低下している。

しかし、統計的特徴量における学習モデルの性能が低いため、全体を通して言語的特徴量における学習モデルが最も高い分類性能を記録する結果となった。

表 4.6は正解データとしたTripadvisorにおける観光地のランキングと、表 4.5において最も高性能を記録した言語的特徴量と言語的特徴量(順位相関係数 > 0.4)における学習モデルに対して、2017年12月におけるTwitterデータを適用してランキングした結果である。結果として、TripAdvisorとTwitterにおけるランキングでは非常に大きな差異が存在することが分かる。また、回帰分析における順位相関を特徴量選択に利用した場合では、地理的な単語が特徴量から取り除かれるがランキングの上位においては大きな差異が存在しないことが確認された。表 4.7はTripAdvisorにおける学習モデルに対して、各観光地におけるツイートの総投稿数の変化を考慮した上でランキングした結果である。このとき、特定の観光地 N におけるスコア $Score'_N$ は学習モデルから算出される $Score_N$ を用いて、以下のように計算される。

$$Score'_N = \Delta Tweet_N \cdot Score_N \quad (\Delta Tweet_N > 0) \quad (4.2)$$

ここで、 $\Delta Tweet_N$ は前月比のツイートの総投稿数の増加率である。ただし、月別でのツイートの総投稿数には一定の誤差が存在するため、以下の検定を用いて異常値を判定する。

$$\Delta Tweet_N > \mu + 2\delta, \quad \Delta Tweet_N < \mu - 2\delta \quad (4.3)$$

このとき、 μ は $\Delta Tweet_N$ における平均、 δ は標準偏差である。この有意点 $\mu \pm 2\delta$ との不等式を満たさない場合には1、満たす場合にはその増加率を式 4.2に適用する。結果として、観光地のランキングに大きく変動があることが見て取れる。12月は時期としてクリスマスや年末などの行事が多く、これらに関係すると考えられる観光地の順位が変動している。

第5章

考察

本実験では、言語的特徴量と統計的特徴量において、ロジスティック回帰における分類寄与率を順位相関の観点から考察した上で、ランキング学習に適用した。言語的特徴量では、表 3.1 より、各観光地での単語確率分布に大きな差異が存在することが分かる。ただし、表 3.1 と地理的な名詞において各観光地で非常に大きな偏りがあり、ロジスティック回帰における分類の寄与率のみで特徴量を評価する場合にも同様の傾向が確認されている。しかし、表 4.2 より、各次元における寄与率の順位相関から特徴選択を行う事で観光地に対してのポジティブな印象と考えられる単語の抽出が可能である事が分かる。第 4.1 章より、言語的特徴量は全体的に高い分類性能を記録しており観光地を比較する上で有用な特徴量である事が分かる。ただし、これは地理的な名詞が大きく寄与していると考えられる。そこで、地理的な名詞に対しての前処理を加えた上での各特徴量における分類性能に対しても検証が必要である。また、季節的な名詞である”桜”なども考慮した上で観光地の人気を適切に評価するため、ランキングの時期に応じて季節的な単語に対しての特別な処理などが必要であると考えられる。

統計的特徴量では、ツイート別とユーザ別の統計量の観点からランキング学習における有用性を考察した。ロジスティック回帰における分類の結果から、ツイート別の統計量である投稿曜日、投稿時間、投稿文字数が高い寄与率を持っていることが分かる。第 3.2 章では、累積確率分布の観点から考察するとユーザ別の投稿数においても一定の差異が確認できたが、投稿数 1 に対する分布の偏りが大きく各観光地における特徴量に大きな差異が出にくいため、分類において寄与しなかったと考えられる。ただし、統計的特徴量では、言語的特徴量と比較して次元数が少なく各観光地の特徴を表現するために必要な次元数が不足しているため、分類の性能が全体的に低いと考えられる。加えて、ツイート別の投稿曜日と投稿時間は共に時間的に近い次元間に一定の相関が確認されている。このため、多重共線性の観点からも分類の精度にネガティブな影響を与えた可能性があると考えられる。一般的に、観光地におけるツイートの投稿数などの統計的な数値は、観光地の人気に対して一定の関係性があると考えられる。したがっ

て、統計量の集計をスパースにするなどの工夫をする事で、更に各観光地における人気を正確に反映したランキングの提案が可能になると考えられる。

第 4.2章におけるランキング学習では、ロジスティック回帰における寄与率に対してスピアマンの順位相関係数から特徴選択をすることで、言語的特徴量と統計的特徴量の両方に対してNDCGの改善が確認できた。したがって、ランキング学習における、寄与率に対しての順位相関の観点からの特徴選択はある程度有用であると考えられる。ただし、ペアワイズにおける分類精度は低下しており特徴選択には注意が必要である。このとき、言語的特徴量と統計的特徴量の両特徴量を組み合わせた場合には、分類精度とNDCGの両方の値で改善されていることが分かる。結果として、ペアワイズにおける精度とNDCGの両方で言語的特徴を基にした学習モデルが最も高い性能を記録しており、正確に前処理をした場合には言語的特徴量がランキングをモデル化する上で重要であると考えられる。ただし、前述のように、統計的特徴量は観光地の人気を考慮する上で不可欠であり、再考する必要があると考えられる。

表 4.6の学習モデルに対してツイートを適用したランキングの結果では、Tripadvisorにおける観光地のランキングに比較して、Twitterにおける観光地のランキングで季節行事やイベントが頻繁に開催される観光スポットが上位に位置していることが分かる。例えば、“国立新美術館”、“サンシャインシティ”、“東京国際フォーラム”がランキングの上位4位以内に存在する。これらの観光地には大きな展示ホールなどが存在しており、頻繁に展覧会などのイベントを開催している。また、順位相関が高い次元を選定した特徴量における観光地のランキングでは、地理的な単語などは特徴量から除かれているが、上位の4位以内に位置する観光地には変化が無いことが分かる。以上の結果を踏まえて、表 4.7は各観光地におけるツイートの総投稿数の変化を考慮した上でランキングした結果である。“サンシャイン水族館”、“お台場パレットタウン”、“日本武道館”などの順位が上昇していることが分かる。12月は時期としてクリスマスなどのイベントがあるため、これらの観光地では人気に大きな変化があると考えられる。ただし、これらの結果における有用性に関しては、実際にユーザに対してランキングを提示した上で評価実験を行うことで検証する必要がある。

以上より、本実験において、言語的特徴量が観光地の人気変化を考慮したランキングをモデル化する上で非常に重要であると考えられる。ただし、統計的特徴量は観光地の人気を表現する上で不可欠であり、特徴量における次元数が観光地を分類する上で不足しているため分類性能が低くなっていると推測される。また、正確にランキングをモデル化するため、回帰分析における寄与率の順位相関に着目することで、各特徴量においてNDCGの値が改善した。しかし、ペアワイズでの分類性能は低下しており、言語的特徴量では前処理において地理的単語を削除するなどの工夫が必要である統計的特徴量においては、様々な統計量に着目しモデルの性

能を改善した上で、両特徴量を組み合わせる事で改善が期待できる。加えて、各統計量における変化は観光地のランキングをモデル化する上で寄与しないため、学習モデルを用いて観光地をランキングする上で追加で反映させる必要があると考えられる。結果として、Twitterにおけるランキングでは、イベントなどを頻繁に開催する観光地がランキングの上位に位置するような結果が確認されている。しかし、この観光地のランキングにおけるその有用性に関しては、ユーザ実証実験を通しての検証が必要である。

第6章

まとめと今後の課題

本稿では、観光地の人気の変化に影響する言語的特徴量と統計的特徴量を分析した上で、TripAdvisorにおける観光地のランキングに対して、ツイートを用いてモデル化する事で人気の時間変化を考慮したランキングを生成した。結果として、各特徴量でTripAdvisorにおける観光地のランキングが高い性能でモデル化された。また、ランキング学習に対してロジスティック回帰における寄与率を順位相関の観点から特徴選択することで、ランキング学習においてNDCGが値が向上した。その結果、RankSVMではペアワイズの分類精度として0.79、平均NDCGとして0.89を示した。しかし、ペアワイズの分類精度としては低下しており、統計的特徴量における改善が必要である。全体として、言語的特徴量におけるモデルで最も高い性能を記録した。

今後の課題としては、分類における寄与率など微量選択に対して考慮する必要がある。地理的単語における分類への寄与率が非常に高いため、今回は順位相関のみを利用した。そこで、前処理において地理的な単語を削除することでランキング学習における分類精度の向上が期待できる。また、ユーザに現時点でのTwitterデータを利用した上でのランキング提案をした上での評価を考察する必要がある。実際にユーザに対して、本研究の目的となる来訪時点で最も楽しめる観光地の提案というニーズを満たすランキングが提案できているかを評価実験を行なった上で実証する必要があると考えられる。また、現在の観光地のランキングでは、言語的特徴量においては季節などによる人気の変化が考慮されていない。したがって、“桜”や“雪”などの定期的に出現すると考えられる単語に対して、月別で重みを与えるなどの処理をする必要があると考えられる。最終的には、観光地の人気に影響する特徴量として、各ツイートにおける観光地に対する感情なども特徴量として考慮する必要があると考えられる。

謝辞

本研究に際して、時に厳しく時に優しく様々なご指導を頂きました指導教員の教授 石川博氏に深謝いたします。また、ゼミの際に様々なご指摘を下さいました石川研究室特任助教授 荒木徹也氏、そして、論文の添削をしてくださったり様々な貴重なアドバイスをしてくださった岡山理科大学講師 廣田雅春氏に感謝いたします。そして、首都大学東京石川研究室9期生として、研究室での辛い日々や楽しい日々を共にして、切磋琢磨し励ましあった同輩の皆さんに感謝いたします。

皆様のお力添えがあり、ここに修士論文を完成させることができたことに深く感謝いたします。

平成31年2月22日

参考文献

- [1] Z. Xiang, D. Wang, J.T. O'Leary, and D.R. Fesenmaier, "Adapting to the internet: trends in travelers' use of the web for trip planning," *Journal of Travel Research*, vol.54, no.4, pp.511–527, 2015.
- [2] U. Gretzel and K.H. Yoo, "Use and impact of online travel reviews," *Information and communication technologies in tourism 2008*, pp.35–46, 2008.
- [3] C. Castillo, M. Mendoza, and B. Poblete, "Information credibility on Twitter," *Proceedings of the 20th international conference on World wide web*, ACM, pp.675–684, 2011.
- [4] R. Filieri, S. Alguezaui, and F. McLeay, "Why do travelers trust TripAdvisor? antecedents of trust towards consumer-generated media and its influence on recommendation adoption and word of mouth," *Tourism Management*, vol.51, pp.174–185, 2015.
- [5] A. Mukherjee, V. Venkataraman, B. Liu, and N.S. Glance, "What Yelp fake review filter might be doing?," *ICWSM*, pp.409–418, 2013.
- [6] I. Guy, A. Mejer, A. Nus, and F. Raiber, "Extracting and ranking travel tips from user-generated reviews," *Proceedings of the 26th international conference on world wide web*, International World Wide Web Conferences Steering Committee, pp.987–996, 2017.
- [7] J. Borràs, A. Moreno, and A. Valls, "Intelligent tourism recommender systems: A survey," *Expert Systems with Applications*, vol.41, no.16, pp.7370–7389, 2014.
- [8] S. Loh, F. Lorenzi, R. Saldaña, and D. Licthnow, "A tourism recommender system based on collaboration and text analysis," *Information Technology & Tourism*, vol.6, no.3, pp.157–165, 2003.
- [9] M. Ye, P. Yin, and W.-C. Lee, "Location recommendation for location-based social networks," *Proceedings of the 18th SIGSPATIAL international conference on*

- advances in geographic information systems, ACM, pp.458–461, 2010.
- [10] M. Ye, P. Yin, W.-C. Lee, and D.-L. Lee, “Exploiting geographical influence for collaborative point-of-interest recommendation,” Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval, ACM, pp.325–334, 2011.
- [11] M. De Choudhury, M. Feldman, S. Amer-Yahia, N. Golbandi, R. Lempel, and C. Yu, “Automatic construction of travel itineraries using social breadcrumbs,” Proceedings of the 21st ACM conference on Hypertext and hypermedia, ACM, pp.35–44, 2010.
- [12] K.H. Lim, J. Chan, C. Leckie, and S. Karunasekera, “Personalized trip recommendation for tourists based on user interests, points of interest visit durations and visit recency,” Knowledge and Information Systems, vol.54, no.2, pp.375–406, 2018.
- [13] S. Ishihara, M. Nagamachi, and T. Tsuchiya, “Development of a kansei engineering artificial intelligence sightseeing application,” International Conference on Applied Human Factors and Ergonomics, Springer, pp.312–322, 2018.
- [14] Y. Mizutani and K. Yamamoto, “A sightseeing spot recommendation system that takes into account the change in circumstances of users,” ISPRS International Journal of Geo-Information, vol.6, no.10, p.303, 2017.
- [15] S. Missaoui, M. Viviani, R. Faiz, and G. Pasi, “A language modeling approach for the recommendation of tourism-related services,” Proceedings of the Symposium on Applied Computing, ACM, pp.1697–1700, 2017.
- [16] Y. Duan, L. Jiang, T. Qin, M. Zhou, and H.-Y. Shum, “An empirical study on learning to rank of tweets,” Proceedings of the 23rd International Conference on Computational Linguistics, Association for Computational Linguistics, pp.295–303, 2010.
- [17] A. Gupta and P. Kumaraguru, “Credibility ranking of tweets during high impact events,” Proceedings of the 1st workshop on privacy and security in online social media, ACM, p.2, 2012.
- [18] Y. Chang, A. Dong, P. Kolari, R. Zhang, Y. Inagaki, F. Diaz, H. Zha, and Y. Liu, “Improving recency ranking using Twitter data,” ACM Transactions on Intelligent Systems and Technology (TIST), vol.4, no.1, p.4, 2013.
- [19] T. Joachims, “Optimizing search engines using clickthrough data,” Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data

- mining, ACM, pp.133–142, 2002.
- [20] C.-P. Lee and C.-J. Lin, “Large-scale linear RankSVM,” *Neural computation*, vol.26, no.4, pp.781–817, 2014.
- [21] C.-C. Chang and C.-J. Lin, “LIBSVM: A library for support vector machines,” *ACM Transactions on Intelligent Systems and Technology*, vol.2, pp.27:1–27:27, 2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [22] K. Järvelin and J. Kekäläinen, “Cumulated gain-based evaluation of IR techniques,” *ACM Transactions on Information Systems (TOIS)*, vol.20, no.4, pp.422–446, 2002.

発表論文

学術論文

1. Yusaku Takano, Masaharu Hirota, Daiju Kato, Tetsuya Araki, Masaki Endo, Hiroshi Ishikawa: Adaptive Method for Trends in Ranking of Tourist Spots, The Eleventh International Conference on Information, Process, and Knowledge Management (eKNOW2019) (2019.2)

国内研究会

1. 高野悠作, 加藤大受, 遠藤雅樹, 莊司慶行, 廣田雅春, 石川博: 撮影軌跡の曲率による観光スポットの分析, 第9回データ工学と情報マネジメントに関するフォーラム (DEIMフォーラム2017) (2017.3)
2. 高野悠作, 加藤大受, 遠藤雅樹, 廣田雅春, 荒木徹也, 石川博: 観光地における移動軌跡の曲率分析, 第14回観光情報学会全国大会 (2017.7)